

Systems and Automation Department
Grado en Ingeniería Electrónica Industrial y Automática
Universidad Carlos III de Madrid

Brainwave Controller Development for Intelligent Vehicle

Trabajo Fin de Grado

Autor:	Armando Astudillo Olalla
Tutor:	Ahmed Hussein
Fecha:	6 de Octubre, 2017

Systems and Automation Department
Grado en Ingeniería Electrónica Industrial y Automática
Universidad Carlos III de Madrid

Brainwave Controller Development for Intelligent Vehicle

Trabajo Fin de Grado

Autor:	Armando Astudillo Olalla
Tutor:	Ahmed Hussein
Fecha:	6 de Octubre, 2017

Esto certifica que:

- (i) la tesis comprende sólo mi trabajo original
- (ii) se ha dado el debido reconocimiento en el texto al resto de trabajos utilizados

Armando Astudillo Olalla
6 de Octubre, 2017

Agradecimientos

Este trabajo ha sido posible gracias a la ayuda de muchas personas, a las cuales quisiera agradecer enormemente su apoyo.

Agradezco el empeño realizado por mi tutor Ahmed Hussein, por darme la oportunidad de realizar este proyecto, por guiarme y por darme ánimo a lo largo de tantos meses.

Quisiera agradecer a todas las personas que forman parte del Laboratorio de Sistemas Inteligentes de la Universidad Carlos III de Madrid, en especial a Fran y a Fernando, por la cálida acogida y por reservar su tiempo para permitirme realizar pruebas con ellos.

Por otra parte, no podría haber completado mis estudios sin el esfuerzo incansable de mi familia, mis hermanos y mis padres, quienes me inspiran día tras día.

Finalmente, debo agradecer a mis compañeros de clase, Carlos, Sergio y Roberto, por estar a mi lado y compartir tantos momentos agradables durante estos cuatro duros años.

A todos ellos, y a los que han formado parte de este proyecto, gracias.

Resumen

Las funciones cognitivas del cerebro desempeñan un papel muy importante en la vida cotidiana de los seres humanos, por lo tanto, los patrones de pensamiento mental, que están presentes en las señales neuronales, pueden ser utilizados para mejorar tanto la vida de personas sanas como de personas discapacitadas. Las Interfaces Cerebro-Ordenador (BCI) son sistemas de comunicación, que permiten a los seres humanos interactuar mentalmente con dispositivos y máquinas externas. Detectan, registran y analizan electroencefalogramas (EEG), los cuales reflejan ciertas funciones o mandatos cerebrales.

En este trabajo, la lectura de los datos de EEG se recopilan y clasifican, utilizando un casco BCI de bajo coste y un clasificador del tipo Red Neural (NN). El objetivo es clasificar e identificar las decisiones de ruta de los usuarios, quienes están a bordo de un vehículo automatizado. El sistema aprovecha la capacidad de control autónomo del vehículo, y el sensor de ondas cerebrales permite al usuario tomar la decisión de la ruta.

Se llevaron a cabo varios experimentos para el entrenamiento del clasificador, además, se realizaron numerosos experimentos de ensayo. Los resultados obtenidos muestran una clasificación exitosa de las decisiones de los sujetos, mejorando la capacidad de movilidad de las personas con discapacidad física.

Palabras clave: Brain-Computer Interface, Electroencefalograma, Ondas Cerebrales, Machine Learning, Red Neuronal, Vehículo Autónomo.

Índice

Agradecimientos	V
Resumen	VII
1 Introducción	1
1.1 Motivación	1
1.2 Objetivos	1
1.3 Estructura del trabajo	2
2 Estado del Arte	3
2.1 Introducción al Machine Learning	3
2.1.1 Redes Neuronales	3
2.1.2 Clasificadores del tipo “Support Vector Machine”	4
2.2 El cerebro humano	5
2.3 El electroencefalograma	6
2.3.1 El descubrimiento de las ondas cerebrales	6
2.3.2 Tipos de ondas cerebrales	7
2.4 Brain-Computer Interfaces	7
2.4.1 Tipos de BCI	8
2.4.2 Trabajos realizados con BCI	8
3 Plataforma	11
3.1 Hardware	11
3.1.1 Sensor de ondas cerebrales	11
3.1.2 Vehículo autónomo	12
3.2 Software	12
3.2.1 Robotic Operating System	12
3.2.2 Ordenador personal	12
4 Metodología	15
4.1 Ondas y Características a Extraer	15
4.2 Adquisición de Datos	15
4.3 Filtrado de Datos	16
4.4 Procesamiento de Entradas	16
4.5 Clasificadores Propuestos	17

4.5.1	Clasificador General	18
4.5.2	Clasificador Individual	19
5	Trabajo Experimental y Resultados	21
5.1	Experimento 1	21
5.2	Experimento 2	22
5.3	Encuesta al Usuario	24
6	Conclusiones y Trabajos Futuros	27
	Apéndice	29
A	Lista de Abreviaturas	30
	Lista de Abreviaturas	30
	Lista de Figuras	31
	Lista de Tablas	32
B	Marco Legislativo	33
C	Aspecto Socio-Económico	34
	Referencias	37

Capítulo 1

Introducción

1.1 Motivación

El ser humano cada vez vive más años, según el Instituto Nacional de Estadística (INE), en 2013 había cerca de 13.000 personas en España con más de 100 años [1]. Esto significa que la robótica aplicada en la biomedicina es un campo que experimenta un crecimiento constante y necesario para asegurar una calidad de vida digna para estas personas.

Para alcanzar dicho objetivo, se emplean diferentes técnicas como las basadas en prótesis activadas mediante impulsos eléctricos generados en los músculos (EMG), este tipo de métodos no son aplicables a personas con algún tipo de afección neuronal, ya que la información no se transmite de forma correcta por el sistema nervioso central, sin embargo, si medimos la actividad cerebral mediante el uso de encefalogramas (EEG), podemos llegar a identificar dichos impulsos en la mayor parte de los sujetos. Estos métodos de comunicación entre el cerebro y el ordenador se denominan Interfaces Cerebro-Ordenador (del inglés, “Brain-Computer Interfaces”, BCI).

El principal problema de estas técnicas radica en el alto coste de los dispositivos necesarios, por ello, este trabajo ofrece una primera aproximación de un sistema comercial de bajo coste basado en BCI.

1.2 Objetivos

El principal objetivo de este trabajo es desarrollar un sistema capaz de identificar, mediante algoritmos basados en Redes Neuronales (NN), la ruta a tomar por un vehículo automatizado mediante la lectura de EEG usando un sensor low-cost para que sea accesible a la mayor parte del público posible.

Este sistema debe ser capaz de:

1. Adquirir los datos de forma correcta enviados por el sensor.

2. Procesar el electroencefalograma (EEG) y obtener características útiles para el clasificador.
3. Desarrollar un clasificador capaz de identificar la dirección que ha de tomar el vehículo.

Se desarrollarán dos soluciones: la primera será obtener un clasificador general, es decir, un algoritmo capaz de identificar la dirección sin necesidad de un entrenamiento específico; la segunda será desarrollar un clasificador individual, es decir, un algoritmo entrenado de forma personal para cada sujeto.

1.3 Estructura del trabajo

A continuación se describirá brevemente el contenido de cada capítulo a tratar:

- **Capítulos 1 y 2:**

Se expone el concepto de BCI y de cómo de útil puede llegar a resultar para la sociedad.

Se introduce el concepto de “Machine Learning” y los dos tipos de clasificadores que se van a emplear (Red Neuronal y Máquinas de Soporte Vectorial).

Se explica el funcionamiento eléctrico del cerebro humano y el descubrimiento de las ondas cerebrales.

Para finalizar, se describen varios experimentos realizados en el campo de las Interfaces Cerebro-Ordenador y de la tecnología que se emplea.

- **Capítulo 3:**

Se enumeran y se describen brevemente los dispositivos que se usarán en este trabajo.

- **Capítulo 4:**

Se explica paso a paso la técnica implementada para la extracción de las EEG y su correspondiente procesamiento y clasificación.

- **Capítulo 5:**

Se describen los experimentos realizados en este trabajo, así como los resultados obtenidos.

- **Capítulo 6:**

Se realiza una exposición objetiva de los resultados y del trabajo realizado, y se enumeran una serie de objetivos para trabajos futuros.

Capítulo 2

Estado del Arte

En este capítulo se hará una breve introducción al denominado “Machine Learning” y a las técnicas más relevantes en la historia de “Brain-Computer Interfaces”.

2.1 Introducción al Machine Learning

El aprendizaje automático de una máquina (del inglés, “Machine Learning”) es un campo que proviene de las ciencias de computación, cuyo objetivo fundamental es desarrollar técnicas de control inteligente que permitan a las máquinas aprender determinados comportamientos a partir de ejemplos dados. Se emplean para resolver problemas muy complejos y realizar casi cualquier proceso de forma autónoma.

A continuación se describirán dos de estas técnicas: las Redes Neuronales (NN), y los clasificadores del tipo Máquinas de Soporte Vectorial (del inglés, “Support Vector Machine”, SVM).

2.1.1 Redes Neuronales

Una Red Neuronal (Figura 2.1) es una técnica de aprendizaje para máquinas la cual posee una estructura capaz de procesar información mediante varios elementos interconectados (neuronas) dispuestos en diferentes capas. Cada neurona es activada o inhibida por sus neuronas adyacentes, estas neuronas operan mediante funciones de suma y lógica simple.

Estos sistemas son capaces de identificar patrones y resolver problemas complejos de forma análoga a como lo haría el cerebro humano.

Los primeros modelos de redes neuronales fueron propuestos por McCulloch y Pitt en 1943 y supusieron un nuevo enfoque para las aplicaciones de inteligencia artificial.

A finales de la década de los 40, el neurocientífico canadiense Donald Hebb desarrolló el primer método de aprendizaje para redes neuronales asentando las bases de los modelos de aprendizaje no supervisado y superando sencillos test de Turing.

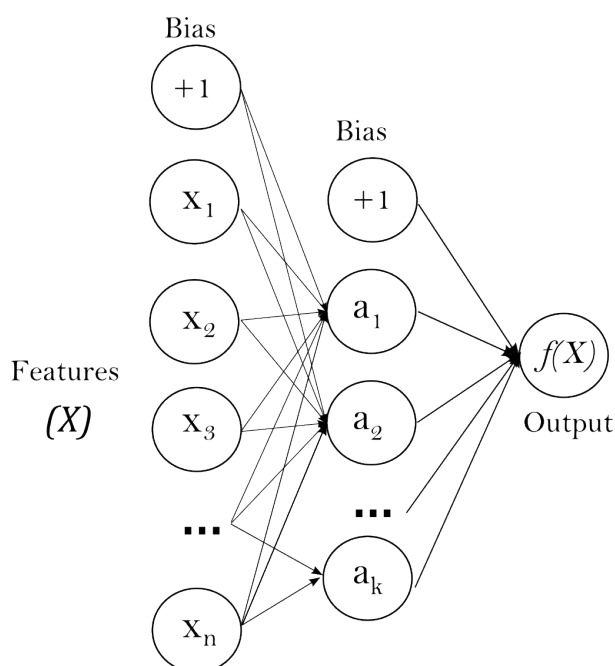


Figura 2.1: Grafo de una Red Neuronal artificial. (Fuente: Scikit-Learn).

En 1958, el científico Frank Rosenblat (Figura 2.2) demostró la capacidad de estos algoritmos para el reconocimiento de patrones mediante el modelo “Perceptron”.




Figura 2.2: Frank Rosenblat ajustando un modelo perceptron en 1960.

Se produjo un parón significativo desde 1960 hasta mediados de los 80, esto se debió a las limitaciones de procesamiento de los ordenadores de la época. Por ello, con la

invención de los primeros microprocesadores, los algoritmos basados en redes neuronales resurgen y aparecen nuevos modelos matemáticos. El más importante fue desarrollado por David E. Rumelhart en 1986, quien creó el modelo “Backpropagation”, un algoritmo de aprendizaje no supervisado por el cual se compara el resultado obtenido por la red con la salida deseada, se calcula una señal de error y se transmite “hacia atrás” recalculando el peso de cada neurona, mediante un proceso de optimización por gradiente de una función de coste.

A partir de 1990, el uso de las redes neuronales en el denominado “Machine Learning” ha ido creciendo hasta tal punto que, en la actualidad, los algoritmos basados en estos modelos son algo común en campos como la visión por computador, los sistemas de control, el reconocimiento facial y de voz, y sistemas de aprendizaje automáticos para la resolución de problemas complejos.

2.1.2 Clasificadores del tipo “Support Vector Machine”

Los clasificadores SVM son un conjunto de algoritmos basados en modelos estadísticos capaces de crear hiperplanos en los cuales se disponen las muestras en función de la clase a la que pertenecen.

Estos modelos, al principio lineales, fueron inventados por Vladimir N. Vapnik y Alexey Ya. Chervonenkis en 1963. Al igual que con las redes neuronales, fueron abandonados hasta la creación de los nuevos microchips, y en 1992, de nuevo Vladimir N. Vapnik, junto a Bernhard E. Boser e Isabelle M. Guyon desarrollaron nuevos modelos de clasificadores no lineales dividiendo el espacio en diversas superficies.

Según el núcleo (del inglés, “kernel”) en el que esté basado el modelo matemático, obtendremos diferentes resultados, como se observa la Figura 2.3, la cual muestra los hiperplanos creados para un espacio multiclase.




Figura 2.3: Ejemplo de clasificacion según el kernel empleado. (Fuente: Scikit-Learn).

En la imagen superior se aprecian las superficies de las clases estimadas por los clasificadores SVM para un conjunto de muestras las cuales pueden pertenecer a tres clases (azul, blanco o rojo). Según la distribución de las muestras, será más útil emplear un kernel u otro.

2.2 El cerebro humano

El estudio del cerebro humano ha sido uno de los campos de investigación que más ha llamado la atención a los científicos desde hace miles de años. Se sabe que ya los Egipcios, hace más de 5.000 años, realizaron los primeros descubrimientos en el ámbito de la neurociencia, practicaban diagnósticos relacionados con afecciones neurológicas y realizaban simples operaciones. Desde entonces, las técnicas médicas han mejorado considerablemente, y en la actualidad, otras ciencias como la ingeniería y la física se interesan en el funcionamiento del cerebro y sus posibles aplicaciones prácticas.

El cerebro está dividido en distintos lóbulos, cada uno de ellos está especializado en determinadas actividades tales como el uso de la memoria, la actividad motora o la

resolución de problemas lógicos. En la Figura 2.4 se muestra la disposición del cerebro según sus lóbulos.




Figura 2.4: Cerebro humano con sus lóbulos diferenciados. (Fuente: Md Health.)

- **Lóbulo Frontal:**

El Lóbulo Frontal se encuentra en la parte más anterior del cráneo, se sitúa justo detrás de la frente. Está a su vez dividido en otras cuatro partes: el córtex prefrontal, el córtex orbitofrontal, el córtex primario-motor y el córtex premotor.

Es el encargado de las tareas cognitivas, es decir, se encarga de mantener la atención necesaria para la resolución de problemas, planear tareas y expresarse correctamente. En él también residen las habilidades sociales como la comprensión del sarcasmo, la decepción y el humor, además del reconocimiento de las emociones, la empatía y otro tipo de procesos mentales.

- **Lóbulo Parietal:**

El Lóbulo Parietal, situado en la zona de la cima craneal y la coronilla, se ocupa del control visual y de la percepción del tacto mediante el control de distintas variables como son: la presión, la temperatura, el dolor; y la manipulación de objetos.

Si se produce algún daño en ésta zona, podría verse dañada la habilidad de hablar, el control ocular, y la posibilidad de realizar varias tareas al mismo tiempo.

- **Lóbulo Temporal:**

El Lóbulo Temporal se localiza en la parte baja del cráneo. A él se le asocian diversas tareas, entre ellas se encuentra la capacidad de la memoria a largo plazo,

las respuestas emocionales, y la percepción auditiva. Dentro de él hay una zona conocida como hipocampo, donde la información pasa de la memoria a corto plazo a la memoria a largo plazo.

- **Lóbulo Occipital:**

El Lóbulo Occipital se encuentra en la zona posterior del cráneo, a la altura de la nuca. Es el encargado de procesar los estímulos visuales, dar forma y color a los objetos, y detectar el movimiento.

2.3 El electroencefalograma

Se denomina electroencefalograma (EEG) al gráfico en el que se registra la actividad eléctrica cerebral. Típicamente se emplea como una técnica para detectar anomalías en el funcionamiento del cerebro. La Figura 2.5 muestra el aspecto que tiene una gráfica genérica de EEG.




Figura 2.5: Actividad cerebral registrada con diferentes electrodos. (Fuente: About Kids Health).

2.3.1 El descubrimiento de las ondas cerebrales

El cerebro es el órgano encargado de procesar y ejecutar las señales del sistema nervioso central. Este sistema recoge la información de diferentes nervios y se transmite a través de las neuronas hasta llegar al cerebro, quien lo analiza y manda diversas órdenes mediante otras neuronas. La comunicación entre las neuronas que conforman este sistema se lleva a cabo mediante la sinapsis, un proceso biológico por el cual se genera actividad eléctrica proveniente de la reacción de sustancias químicas producidas por la neurona emisora.




Figura 2.6: Fotografía de una neurona por MethoxyRoxyl. (Bajo licencia CC).

El primer avance realizado en la construcción del mapa cerebral vino de la mano del neurólogo alemán Hans Berger, quien en 1924 dedujo la existencia de ondas cerebrales, poco después logró demostrar su teoría mediante unos electrodos insertados en la corteza cerebral de un sujeto con los cuales se pudieron detectar oscilaciones eléctricas en el cerebro, creando así el primer encefalograma humano.

2.3.2 Tipos de ondas cerebrales

A partir de este primer descubrimiento sobre las ondas cerebrales, se estudió la relación entre diversas acciones como la resolución de operaciones matemáticas o dormir, y la actividad cerebral.

Se determinaron varios tipos de ondas cerebrales dependiendo de la frecuencia en la que están moduladas y la actividad que se está realizando:

- **Delta:** en el rango de 0.5 a 2.75 Hz, se generan durante procesos de sueño profundo. Las actividades de recuperación se producen en este estado, por ello es esencial el buen descanso.
- **Theta:** en el rango de 3.5 a 6.75 Hz, se generan durante procesos de alta relajación. En este estado el sujeto se encuentra soñando y están relacionadas con procesos de memorización e imaginación.
- **Alpha:** en el rango de 7 a 12 Hz, se generan durante procesos de relajación y descanso cerebral. Las actividades asociadas son el aprendizaje y pensamientos en estado de calma.

- **Beta:** en el rango de 13 a 30 Hz, se generan durante procesos de alta concentración. Las actividades como la resolución de problemas o el control del movimiento del cuerpo aumentan la amplitud de estas ondas. Por ello, nos centraremos en estas ondas en este estudio.
- **Gamma:** por encima de los 31 Hz, son las ondas más rápidas y se generan en situaciones de estrés. En este estado las acciones acto-reflejo son más rápidas.

2.4 Brain-Computer Interfaces

Las Interfaces Cerebro-Ordenador (BCI) son técnicas de comunicación que, mediante la lectura de las EEG, permiten manejar una máquina o un dispositivo. Es un método que se ha comenzado a desarrollar desde la última década del Siglo XX. Esta tecnología podría resultar de gran utilidad para personas con algún tipo de parálisis o afección neurológica, como puede ser la producida por una lesión medular, y para personas con problemas de movimiento y coordinación.

No fue hasta la década de los 90 cuando se realizó el primer sistema BCI, este método, desarrollado por el doctor Philip Kennedy, consistía en un electrodo intracortical, es decir, el sensor se implantaba directamente sobre la corteza cerebral. Este tipo de técnicas son muy precisas ya que se puede medir la actividad individual de cada neurona (Figura 2.7), sin embargo, el cerebro rápidamente aísla y rechaza estos dispositivos.




Figura 2.7: Disparo de una neurona y su símil como señal analógica y digital. (Fuente: Paul King, Quora)

2.4.1 Tipos de BCI

Las técnicas de BCI pueden dividirse según el grado de proximidad del sensor al cerebro (Figura 2.8). A continuación, se describirán estos procedimientos yendo de más invasiva a menos invasiva:

- **Invasiva:** Son dispositivos cuyos sensores se insertan directamente sobre la corteza cerebral, esta técnica permite obtener una resolución de la actividad cerebral muy alta, ya que se pueden observar los disparos individuales de cada neurona como se muestra en la Figura 2.7. Sin embargo, el sistema inmunitario, al detectar la presencia de un cuerpo extraño lo encapsula rápidamente dejándolo fuera de uso.
- **Parcialmente Invasiva:** Los sensores se implantan justo bajo la superficie craneal, también precisan de una operación quirúrgica y la resolución es alta, es decir, no podemos observar cada neurona, pero sí observar pequeñas regiones cerebrales de interés con muy poco ruido.
- **No Invasivas:** La idea fundamental de este método consiste en usar sensores que permitan obtener datos de las ondas cerebrales sin necesidad de operaciones. Para ello, se usan dispositivos tales como cascos de BCI (Figura 2.9) compuestos por múltiples sensores, o como en nuestro caso, una diadema con un simple sensor seco.




Figura 2.8: Tipos de BCI. (Fuente: E. Astrand en [2]).

2.4.2 Trabajos realizados con BCI

Desde comienzos del último siglo, el avance realizado en el campo de las Interfaces Cerebro-Ordenador ha sido muy significativo debido a la gran cantidad de mejoras en cuanto al hardware empleado (computadoras, microprocesadores, sensores electrónicos) y a nuevos avances en la modelización de algoritmos de control inteligente e identificación de sistemas. A continuación, se expondrán algunos de los estudios más relevantes basados en BCI.

En 2001, Guger et al. desarrollaron un modelo de BCI para clasificar patrones de EEG cuando un sujeto pensaba en movimientos con la mano izquierda o derecha. Este modelo tuvo una tasa de acierto variable entre el 70% y el 95%. Se basaba en un modelo de predicción autorregresivo adaptativo (AAR) y un discriminador lineal (LDA). Para ello, se llevó a cabo una serie de experimentos mediante un casco de BCI como el de la Figura 2.9, el cual posee múltiples sensores dispuestos por toda la cabeza. En este caso, se emplearon los sensores C3 y C4 según la disposición estándar 10-20 [3] mostrada en la Figura 2.10, los cuales se centran en las áreas motora y somatosensora del cerebro [4]. En 2003, este equipo perteneciente al Graz, publicó un dataset para una competición, la cual consistía en realizar modelos para el reconocimiento de patrones cerebrales para ser probados en cascos de BCI [5]. Este dataset fue realizado de forma independiente para cada sujeto, es decir, el consiguiente clasificador era específico para cada persona y debía ser reajustado para cada sujeto.




Figura 2.9: Casco de BCI. Fuente: BCI-Graz Awards 2016.




Figura 2.10: Sistema de posición 10-20 de electrodos de EEG. (Fuente: Chistopher B. bajo licencia CC).

En 2008, Xu et al. combinaron la Transformada Discreta de Onda (del inglés, “Discrete Wavelet Transform”, DWT) con un modelo autorregresivo para analizar el dataset propuesto por el Graz, alcanzando una tasa de acierto de clasificación del 90% [6].

Uno de los experimentos más prometedores en este campo vino de la mano de un proyecto de la DARPA (Department Advanced Research Projects Agency) a finales de 2012 [7]. Un grupo de investigadores lograron que una mujer tetraplégica de mediana edad lograra mover un brazo robótico con gran precisión. Para ello, le implantaron dos sensores intracorticales de 96 canales. La información que este dispositivo enviaba al ordenador era inmensa y tras aproximadamente 13 semanas de entrenamiento, el sujeto era capaz de manejar el brazo en cualquier dirección espacial, e incluso agarrar y manejar objetos simples.

Los avances en BCI se han visto incrementados estos últimos años debido a nuevos dispositivos comerciales de bajo coste, y fáciles de vestir, que permiten realizar trabajos de investigación accesibles para la mayoría de las personas, sin embargo, tan sólo estamos al comienzo de un largo camino con este tipo de sistemas, ya que si se desea un dispositivo más preciso, que disponga de varios sensores de EEG, el precio se eleva rápidamente. Algunos de estos proyectos se han llevado a cabo con dispositivos Neurosky Mindwave. En 2013, L. Al-Barrak y E. Kanjo en [8], estudiaron la precisión de la tecnología de Neurosky para medir los niveles de atención y meditación, lo hicieron mediante diferentes pruebas psicológicas tales como los experimentos de Stroop, los cuales se suelen emplear para inducir estrés al sujeto y así poder medir los niveles de atención y meditación, y compararlos con los resultados obtenidos por el dispositivo de EEG.

Por otra parte, en [9] los autores experimentaron con la posibilidad de controlar un robot real usando dos cascos diferentes: el Neurosky Mindwave y el Emotiv Epoc (compuesto por más de una decena de sensores). Ellos diseñaron un sistema de interacción

humano-robot de coste medio-elevado usando estos dos dispositivos y diversos componentes para la teleoperación de robots. En [10], se investigó sobre el control de una silla de ruedas usando ondas cerebrales, teniendo en cuenta algunas restricciones del día a día, como la limitada energía eléctrica, el tamaño y peso de la silla, el coste, y la rapidez en la toma de decisiones. Otro estudio realizado en 2011 llevó a cabo una serie de experimentos para determinar la posibilidad de estimar el sentido (izquierda o derecha) en el que pensaba un sujeto usando el dispositivo Neurosky Mindwave y un clasificador del tipo red neuronal (NN), sin embargo, los resultados no fueron concluyentes y no se pudo determinar un clasificador eficaz con ese sensor, así pues propusieron la detección del guiño de ojos para cambiar de dirección, en lugar de la actividad mental [11].

Capítulo 3

Plataforma

En este capítulo se explica el sistema hardware y software empleado para llevar a cabo los experimentos tanto de entrenamiento como de prueba.

3.1 Hardware

El sistema hardware empleado consiste en un casco lector de ondas cerebrales y un vehículo automatizado, los cuales se describen a continuación.

3.1.1 Sensor de ondas cerebrales

Para la lectura del encefalograma del sujeto, se empleará el dispositivo de bajo coste Mindwave Mobile (Figura 3.1), desarrollado por la empresa Neurosky. Dicho casco consta de dos sensores secos: uno se sitúa en la frente, el cual obtiene los datos de las ondas, y el otro sensor se emplea como referencia a masa y está situado en la oreja izquierda.

Dentro del dispositivo se encuentra un microchip capaz de procesar la señal cruda obtenida por el sensor (Figura 3.2). Se realiza la Transformada Rápida de Fourier (FFT) mediante la cual se logra dar una amplitud individual para cada onda, y se envían vía Bluetooth a un ordenador. La amplitud de cada onda varía de 0 a 255, sin embargo, la amplitud para los niveles de atención y meditación varían de 0 a 100.



Figura 3.1: Casco Mindwave Mobile. (Fuente: Neurosky).




Figura 3.2: Salida cruda obtenida del Mindwave Mobile.

3.1.2 Vehículo autónomo

El sensor explicado en el apartado anterior se va a probar sobre un vehículo autónomo (Figura 3.3), el cual forma parte del proyecto “Intelligent Campus Automobile” (iCab) del Laboratorio de Sistemas Inteligentes (LSI) de la Universidad Carlos III de Madrid [12].

El vehículo es un carrito eléctrico de golf el cual está equipado con múltiples sensores tales como un sensor LI-DAR, una cámara estereo, encoders ópticos en las ruedas, un magnetómetro digital y un módulo GPS. Además, el vehículo dispone de un ordenador para procesar toda la información que recibe de los diferentes sensores, dicho ordenador posee una interfaz Bluetooth integrada para la conexión con el sensor de lectura de EEG.



Figura 3.3: Vehículo inteligente “iCab” con un pasajero usando el sensor de ondas cerebrales.

3.2 Software

En esta sección se hablará de la plataforma software para el control de los sensores, del ordenador utilizado, y de los programas necesarios para su puesta a punto.

3.2.1 Robotic Operating System

Tanto los algoritmos del sistema de sensores del iCab, como el código para la lectura de las ondas y su procesamiento, están implementados bajo la arquitectura Robotic Operating System (ROS). ROS es un sistema middleware el cual sirve como puente entre diferentes programas y aplicaciones robóticas.

El algoritmo de adquisición de datos está basado en el trabajo realizado en [13], sin embargo, dicho trabajo se limita a leer y procesar tan sólo los niveles de atención y meditación. Así pues, este trabajo se extiende incluyendo la lectura de todas las ondas y la extracción de más características para una mejor clasificación, la cual se explica en el apartado de metodología.

Otro sistema embebido en el mismo ordenador es el encargado de la navegación autónoma y la toma de mediciones de los diferentes sensores. Este sistema es capaz de monitorizar el entorno en todo momento gracias a los subsistemas de percepción, localización y control implementados también en ROS [14].

3.2.2 Ordenador personal

El ordenador empleado para procesar la información del casco de BCI es un Acer Aspire F15 de 2016, posee un procesador i7-6500 con una tarjeta gráfica Nvidia 940Mx.

Se usa el sistema operativo de libre distribución Linux Ubuntu 16.04 LTS en el que se instala Python 2.7, las librerías para Python: Scikit-Learn, Numpy y SciPy, las cuales nos proporcionan las herramientas matemáticas necesarias para el procesamiento y análisis de las ondas cerebrales; y ROS en su versión Kinetic. Como editor de texto, en este caso, se ha empleado Sublime Text 2.

Capítulo 4

Metodología

En este capítulo se explicará la técnica empleada para la adquisición de las ondas y las características extraídas para su consiguiente procesamiento y análisis. Además, se presentará el clasificador empleado, es decir, las entradas utilizadas y la salida obtenida, así como su algoritmo interno.

4.1 Ondas y Características a Extraer

Según la clasificación explicada en los tipos de ondas cerebrales, las entradas que emplearemos en nuestro algoritmo serán: Low Beta (13-16.75 Hz), High Beta (18-29.75 Hz), Beta, Envolvente de Beta, Derivada de Beta, Atención y Derivada de Atención. Para la obtención de estas ondas partiremos de los datos de Atención, Low Beta y High Beta, los cuales provienen de la salida directa del dispositivo Mindwave, dichos datos tienen un aspecto como el mostrado en la Figura 4.1.

4.2 Adquisición de Datos

El casco de EEG emplea el sistema de comunicación “ThinkGear Communications Protocol” para conectarse vía Bluetooth al ordenador [15]. Una vez se ha establecido la conexión entre el dispositivo y el ordenador, la información ha de ser extraída correctamente desde el paquete de datos (del inglés, “Payload”), dicho paquete se recibe como una secuencia de datos clave-valor, la cual se define en la Tabla 4.1. El script decodificador lee el vector entero de datos y guarda cada valor en su correspondiente variable.

Una de las partes más importantes de este método reside en el algoritmo de decodificación de las EEG, ya que se reciben en forma de un único vector de datos cuyo formato es el “Big-Endian”, lo que significa que hay 24 Bytes de enteros sin signo continuos para las 8 ondas, es por ello que se debe dividir este vector y convertirlo a decimal.




Figura 4.1: Salida muestreada desde el dispositivo Mindewave Mobile.

Tabla 4.1: Tabla de definición clave-valor.

Code	Data Meaning
0x02	Signal Quality
0x04	Attention Level
0x05	Meditation Level
0x83	EEG Array

4.3 Filtrado de Datos

Una vez se ha decodificado el paquete de datos, comienza el procesamiento de las lecturas obtenidas.

El primer paso consiste en filtrar los datos repetidos. Debido a la conexión por Bluetooth con ROS, el sistema recibe los datos con una frecuencia que varía entre 0.2Hz y 0.5Hz, un ratio muy bajo para un método BCI. Si seguimos el Teorema de Nyquist (4.1), la frecuencia de obtención de datos ha de ser al menos el doble de la frecuencia de la señal de entrada. Por lo que la cantidad de datos repetidos es muy elevada, alcanzando una media de 1 dato nuevo cada 5 segundos, uno de los hándicap del uso de elementos low-cost.

$$f_{Nyquist} \geq \frac{f_{input}}{2} \quad (4.1)$$

4.4 Procesamiento de Entradas

Tras haber filtrado los datos útiles, las muestras se van a transformar al formato de entrada del clasificador. Como se ha mencionado anteriormente, el formato consiste en 7 entradas provenientes de ondas específicas. La Figura 4.2 muestra un ejemplo del nuevo formato para estas entradas.




Figura 4.2: Formato de entrada para los clasificadores.

Para la obtención de las derivadas de las ondas ($d(W_x)$), se analiza el comportamiento de la onda completa para determinar cuándo es creciente o decreciente, según (4.2).

$$d(W_x) = \begin{cases} 1 & ,if \ W_x(t) < W_x(t+1) \\ 0 & ,if \ W_x(t) = W_x(t+1) \\ -1 & ,if \ W_x(t) > W_x(t+1) \end{cases} \quad (4.2)$$

La adquisición de la envolvente de la onda Beta consiste en realizar la media entre las curvas de la envolvente superior e inferior de Beta (4.3). Estas dos curvas se obtienen realizando una interpolación cúbica, este tipo de aproximación proporciona un ajuste excelente y su cálculo no precisa de mucho coste computacional, la Figura 4.3 muestra las diferencias entre usar una interpolación lineal o cúbica. Para llevar a cabo esta operación, el algoritmo se implementa mediante el uso de la librería SciPy.

$$Env_{Beta}(t) = \frac{Env_{LowBeta}(t) + Env_{HighBeta}(t)}{2} \quad (4.3)$$




Figura 4.3: Ejemplo de interpolación lineal y cúbica.

4.5 Clasificadores Propuestos

A fin de dar sentido a los datos obtenidos, el clasificador que se propone a continuación categoriza el sentido en el cuál el sujeto está pensando (izquierda o derecha).

Se presentan dos soluciones para este trabajo, la primera solución trata de un clasificador general, es decir, un clasificador obtenido de muestras de varias personas que sirva para determinar la dirección en la que piensa cualquier sujeto sin necesidad de un entrenamiento previo; el segundo clasificador propone una solución individual para cada sujeto, se entrena el algoritmo con varias sesiones de una misma persona para una mayor precisión.

4.5.1 Clasificador General

La solución que se presenta es un algoritmo fundamentado en el uso de redes neuronales [16], las cuales son modeladas como un perceptrón multi-capas basado en el método de optimización Quasi-Newton para la función de coste logarítmica descrita en (4.4).

$$V(f(\vec{x}), y) = -y \cdot \ln(f(\vec{x})) - (1 - y) \cdot \ln(1 - f(\vec{x})) \quad (4.4)$$

La función de activación para las capas ocultas de las redes implementadas es la denominada Función Rectificada Lineal (RELU), según (4.5).

$$f(x) = \max(0, x) \quad (4.5)$$

donde x es la entrada a cada neurona.

La estructura de la red neuronal consiste en una capa de entrada, tres capas ocultas, y una capa de salida con una única neurona. Todas estas redes son modeladas mediante Scikit-Learn, una librería de “Machine Learning” para Python [17]. Para llevar a cabo el entrenamiento de la red, el set de muestras grabadas durante el experimento se divide en un set de entrenamiento y otro de pruebas.

El objetivo es diferenciar entre dos estados, pensar en izquierda o pensar en derecha, así pues, el algoritmo propuesto se compone de cuatro diferentes redes neuronales, dos para cada dirección. La salida de cada clasificador genera dos clases:

- C_0 : si el sujeto no está suficientemente concentrado.
- C_1 : si el nivel de atención es el necesario para estar pensando en el movimiento.

Además, cada clasificador devuelve una salida por cada instante de lectura, sin embargo, a fin de obtener un resultado robusto, se precisa de una lectura de varias muestras. Así pues, la salida de cada clasificador es predicha comparando, para cada muestra obtenida, la probabilidad de pertenecer a una determinada clase (4.6) y el ratio de error (4.7), el cual depende directamente del nivel de atención.

$$Distance_{sense} = \sum_{i=0} (|P(x_i|C_0) - P(x_i|C_1)|) \quad (4.6)$$

$$Error_{sense} = \frac{Number\ of\ failures}{Number\ of\ samples} \quad (4.7)$$

El resultado final tiene tres posibles estados:

1. **NULL**: el resultado no puede ser categorizado.
2. **LEFT**: el sujeto está pensando en la izquierda.
3. **RIGHT**: el sujeto está pensando en la derecha.

4.5.2 Clasificador Individual

La segunda solución propuesta en este trabajo consiste en el desarrollo de un clasificador específico para cada sujeto. Este nuevo clasificador está compuesto por tres modelos diferentes: el primero, Clasificador ‘A’, sigue el mismo método que se ha explicado en la sección “Clasificador General”, el segundo, Clasificador ‘B’, es un algoritmo de una única red neuronal, y el tercero, Clasificador ‘C’, consiste en un modelo basado en un clasificador del tipo SVM. De esta forma se puede comparar qué aproximación tiene mayor relevancia para ser mejorada en estudios posteriores.

De nuevo se vuelve a obtener tres posibles estados para el resultado final:

1. **NULL:** el resultado no puede ser categorizado.
2. **LEFT:** el sujeto está pensando en la izquierda.
3. **RIGHT:** el sujeto está pensando en la derecha.

Clasificador ‘A’

Como ya se ha explicado en el apartado anterior, el Clasificador ‘A’ sigue la misma metodología que el denominado “Clasificador General”, la única diferencia con respecto a este primero radica en las muestras con las que ha sido entrenado, ya que han de ser las del sujeto del que queremos realizar el clasificador y no de un grupo amplio de personas.

Clasificador ‘B’

El segundo clasificador está formado por una única red neural en la que se discrimina directamente el sentido en el que está pensando el sujeto, es decir, las nuevas clases a las que puede pertenecer son C_0 (izquierda) o C_1 (derecha), y por ende, el dataset de este clasificador estará compuesto por las muestras de pensamiento izquierdo y derecho juntos. Las entradas de esta red son las mismas que las del Clasificador ‘A’, por lo que necesitaremos un mínimo de 6 datos para poder realizar la envolvente de Beta.

Como ya se ha mencionado, este clasificador es una ligera variante del Clasificador ‘A’, por lo que para determinar el resultado de este modelo se realiza una comparación entre las probabilidades de pertenencia a una clase o a la otra (4.8).

$$Distance_{global} = \sum_{i=0} (|P(x_i|C_0) - P(x_i|C_1)|) \quad (4.8)$$

Clasificador ‘C’

El tercer y último clasificador es un modelo SVM entrenado con la misma metodología de muestras que el Clasificador ‘B’, es decir, se obtiene un dataset con muestras de un único sujeto que contenga tanto los datos cuando se piensa en la izquierda, como los datos cuando se piensa en la derecha.

El kernel o núcleo de este clasificador sigue la topología Función de Base Radial (del inglés, “Radial Basis Function”, RBF). Se escoge este kernel debido al alto rendimiento que posee, ya que el coste computacional es muy bajo y ofrece unos resultados muy ajustados. La Tabla 4.2 muestra la diferencia de porcentaje de acierto entre un clasificador con núcleo lineal y otro con núcleo RBF. Para probar los diferentes núcleos se han instanciado 200 muestras aleatorias de dos dimensiones, con valores acotados de -10 a 10. Se puede apreciar que el clasificador RBF obtiene unos resultados mucho mejores que el lineal, es por ello que emplearemos éste núcleo.

Tabla 4.2: Comparación de kernel para SVM

Kernel	Score
Lineal	12.0386%
RBF	92.0737%

En este estudio, el hiperplano creado por el algoritmo del clasificador SVM, es de 7 dimensiones, correspondiente a cada una de las entradas a dicho clasificador. Al ser un modelo tan ajustado, por el alto número de entradas, el comportamiento que presenta al clasificar los datos nuevos puede ser ineficaz.

Capítulo 5

Trabajo Experimental y Resultados

El trabajo experimental desarrollado en este proyecto se divide en dos partes: primero, el experimento realizado para el “Clasificador General” (Experimento 1); y la segunda parte, en la cual se explican las pruebas realizadas para el “Clasificador Individual” (Experimento 2).

5.1 Experimento 1

Como ya se ha expuesto anteriormente, el “Clasificador General” consiste en desarrollar un algoritmo capaz de dar un resultado correcto, para cualquier persona, a partir de los datos de entrenamiento de un grupo amplio de sujetos.

Para obtener los datos de entrenamiento de la red neuronal, debemos llevar a cabo sesiones en las que varios sujetos se pongan el casco BCI para leer sus ondas cerebrales mientras piensan en el sentido (izquierda o derecha) que sigue una flecha animada, la cual se les muestra en una pantalla, a la vez que pulsan una tecla con la mano acorde a la dirección de la flecha. Este proceso tiene una duración de un minuto y medio, y se realiza para ambos sentidos. Para este experimento, el sujeto debe concentrarse en mover la flecha con su mente, sin saber que se mueve sola. De forma paralela a esta idea, el sujeto ha de presionar de forma repetida una tecla con la mano correcta, de esta forma el pensamiento en uno solo de los sentidos se refuerza.

Para la flecha animada se ha desarrollado una aplicación HTML en Unity3D, la cual se muestra en la Figura 5.1. Para este experimento, los sujetos se encuentran sentados en una habitación vacía con el propósito de evitar la mayor parte de ruido y otras distracciones.

Una vez obtenidos todos los datos, estos se dividen en datos de entrenamiento y datos de pruebas. El set de datos de entrenamiento alberga el 80% de las muestras y se usa para el aprendizaje de los clasificadores. A continuación, el otro 20% de las muestras se emplea para comprobar la eficacia, a priori, del modelo.

Los resultados del Experimento 1 produjeron 481 muestras provenientes de 34 sujetos diferentes cuyas edades van de los 21 años a los 51 años. Además, el grupo de participantes




Figura 5.1: Flecha animada en Unity3D.

de este experimento estaba formado tanto por hombres como por mujeres, y por diestros y zurdos, con la intención de asegurar la diversidad de las muestras y obtener un set de entrenamiento realmente genérico.

Esta red neuronal fue probada en diferentes arquitecturas, con distinto número de capas ocultas y de neuronas en cada capa. La Tabla 5.1 muestra el porcentaje de acierto obtenido para cada configuración.

Tabla 5.1: Resultados según la arquitectura del Experimento 1.

Hidden Layer Size			Right Score	Left Score
HL 1	HL 2	HL 3		
L	200	None	73.45%	65.62%
L	L/2	None	69.84%	65.62%
L	L/2	L/3	83.33%	75.00%
L	L/2	L/4	83.33%	70.14%

La arquitectura final de la red neuronal consta de tres capas ocultas. El número de neuronas es L para la primera capa, $L/2$ para la segunda, y $L/3$ para la tercera; donde L es el número de entradas a la red. Con esta arquitectura, el acierto en las sesiones de entrenamiento, fue de un **83.33%** para pensamientos en izquierda, y de un **75.00%** para pensamientos en derecha.

Se realizó otro experimento para este clasificador el cual consiste en emplear la plataforma inteligente “iCab”, sin embargo, los resultados no fueron concluyentes debido a diversos factores como: el cambio tan radical que supone un entorno real con respecto a la aplicación HTML, ya que el sujeto está expuesto a múltiples y nuevas distracciones; el ruido en el set de entrenamiento, ya que no todos los sujetos pensaban seriamente en el sentido de la flecha; y a las diferentes formas de pensar de cada sujeto.

5.2 Experimento 2

Este experimento es exclusivo para cada persona, en este trabajo las pruebas han sido realizadas con un sujeto a lo largo de 10 sesiones de entrenamiento.

Para obtener unos datos de entrenamiento consistentes, las pruebas se han llevado a cabo en diferentes días y bajo distintos entornos: en una habitación vacía y en una habitación con gente hablando alrededor. No ha sido preciso el uso de ninguna otra aplicación como la flecha animada del anterior experimento (Figura 5.1) para inducir concentración en el sujeto, ya que, al ser una única persona, debe centrarse en un sentido u otro dependiendo de sus sensaciones. En adición a estas nuevas condiciones, el tiempo de la sesión se ha reducido a 30 segundos, en lugar del minuto y medio del anterior experimento, esto se hace en consideración a disminuir el tiempo que ha de estar concentrado el sujeto, ya que a mayor tiempo de exposición, mayor fatiga y mayor distracción.

Los resultados de este experimento han producido un total de 576 muestras, las cuales, al igual que en el anterior experimento, se dividen en 80% para entrenamiento y 20% para pruebas, a priori, de los tres clasificadores de los que se compone el “Clasificador Individual”. Se ha probado el experimento para diferentes tamaños de muestras de entrenamiento, en la Tabla 5.2 se muestran los tamaños de los dataset de entrenamiento de las redes neuronales del Clasificador ‘B’ y los resultados de acierto obtenidos en la clasificación del otro 20% de las muestras.

Tabla 5.2: Resultados de la sesión de entrenamiento del Clasificador ‘B’.

Número de red	Tamaño del dataset	Train/Test Score
NN-1	292	70.00%
NN-2	449	90.00%
NN-3	576	60.00%

Así pues, una vez se han configurado los distintos clasificadores comenzamos a probar el “Clasificador Individual” mediante las pruebas finales, para ello, el sujeto, de quien son las muestras, se colocará el casco de BCI y comenzará a pensar en el sentido que desee hasta que el programa dé un resultado, que como ya se ha mencionado antes, en este caso tan sólo tendrá que esperar 30 segundos.

El resultado obtenido por el “Clasificador Individual” demuestra la eficacia del Clasificador ‘B’, ya que tanto el Clasificador ‘A’ como el ‘C’ no logran dar un resultado coherente. Sin embargo, el modelo de red neuronal “NN-2” de la Tabla 5.2 ha obtenido un porcentaje de acierto del **83.33%** en la clasificación del sentido izquierdo y del **83.33%** para el sentido derecho, en las sesiones de pruebas finales.

5.3 Encuesta al Usuario

Acorde a estos experimentos se ha realizado una encuesta sobre vehículos autónomos y el uso de técnicas de BCI.

La encuesta está compuesta por preguntas dicotómicas y escaladas, las cuales nos dan información sobre el conocimiento que la gente tiene sobre la tecnología de BCI y la confianza que se tiene sobre estos métodos en sus posibles aplicaciones prácticas. El propósito de esta encuesta radica en obtener una realimentación sobre el uso de BCI en vehículos autónomos, permitiendo así la validación del trabajo realizado para escenarios reales.

Entre todas las preguntas de la encuesta, las respuestas más interesantes provienen de aquellas referentes al conocimiento de los usuarios y la confianza en las tecnologías BCI, que se dividen en dos grupos.

La Figura 5.2 muestra el nivel de conocimiento previo sobre esta tecnología y el nivel de miedo o desconfianza que las BCI generan. Como se puede observar, la mayoría de los usuarios tenían conocimientos previos sobre técnicas de BCI, y un porcentaje similar de los encuestados no tienen miedo a este tipo de tecnología.




Figura 5.2: Izquierda: Conocimiento sobre BCI. Derecha: Desconfianza que producen las técnicas de BCI.

Por otra parte, la Figura 5.3 muestra los resultados de diferentes preguntas, que se centraron principalmente en la confianza en esta tecnología al controlar un vehículo autónomo u otro tipo de dispositivos menos peligrosos como un ordenador.

A pesar de que la mayoría de los usuarios no tienen miedo de la tecnología BCI, el 61,1% de ellos no lo utilizarían para controlar un vehículo autónomo. Estos resultados provienen principalmente de las preocupaciones que implican perder el control del vehículo, y no por la propia tecnología BCI, ya que la mayoría de los usuarios lo usarían para controlar una computadora.




Figura 5.3: Izquierda: Usuarios que controlarían un vehículo con su mente. Derecha: Usuarios que controlarían un ordenador con su mente.

Capítulo 6

Conclusiones y Trabajos Futuros

En este trabajo se propone un nuevo enfoque para la clasificación de ondas cerebrales mediante redes neuronales (NN) usando un lector de EEG de bajo coste. El objetivo principal es usar el casco en un sujeto que está sentado en un vehículo autónomo, mientras los pensamientos sobre la dirección que ha de tomar se transmiten al controlador del vehículo.

Se han llevado a cabo numerosos experimentos para entrenar el denominado “Clasificador General”, un algoritmo que sea capaz de identificar la ruta (izquierda o derecha) que ha de tomar el vehículo, sin necesidad de un entrenamiento específico para cada persona. El resultado obtenido para la clasificación del dataset de entrenamiento muestra el gran potencial del algoritmo propuesto. Sin embargo, en las pruebas realizadas en entornos menos controlados, los resultados fueron inconcluyentes, evidenciando así la necesidad de realizar un clasificador independiente para cada persona.

Los ensayos realizados en la adquisición de un clasificador personalizado para cada sujeto, corroboran las conclusiones obtenidas de los resultados del “Clasificador General”, es decir, para asegurar un sistema BCI eficaz con el dispositivo Mindwave Mobile, se debe realizar un modelo personalizado para cada sujeto.

Para el “Clasificador Individual” se presentan tres métodos: un algoritmo basado en la concatenación de varias redes neuronales, empleado en el “Clasificador General”; un modelo basado en una red neuronal, la cual discrimina el sentido en el que piensa el sujeto; y un algoritmo de máquinas de soporte vectorial (SVM). La solución más acertada se ha logrado con la segunda aproximación, el Clasificador ‘B’, alcanzando un alto porcentaje de acierto para la clasificación de los datos de entrenamiento (**90.00%**), y unos resultados sorprendentes para un sistema BCI de bajo coste en la clasificación del dataset de las pruebas finales, con **83.33%** de acierto bajo distintos entornos, con un tiempo de muestreo de sólo 30 segundos.

Cabe mencionar que, en el desarrollo de este trabajo, se ha realizado una publicación en un congreso de IEEE, más en concreto el congreso ITSC (Intelligent Transportation Systems Conference) que se va a celebrar en Octubre de 2017 en Yokohama, Japón [18]. Este congreso es la jornada insignia anual de la IEEE Intelligent Transportation Systems Society, en la que se exponen nuevos desarrollos teóricos, métodos prácticos, simulaciones analíticas, demostraciones y soluciones a los distintos problemas que se presentan en el campo de los sistemas de transporte inteligente.

Para trabajos futuros se propone el uso de un casco diferente, que posea más sensores y una velocidad de muestreo más rápida, para poder ser integrado de forma óptima en el control de un vehículo autónomo. Esto permite que se puedan clasificar los pensamientos casi en tiempo real con mayor precisión, además de dar la posibilidad al usuario de tomar más decisiones de movimiento tales como avanzar, parar, o dar marcha atrás.

Apéndice

Apéndice A

Lista de Abreviaturas

LSI	Intelligent Systems Laboratory
EEG	Electroencefalograma
BCI	Brain-Computer Interface
INE	Instituto Nacional de Estadística
CC	Creative Commons
NN	Neural Net
SVM	Support Vector Machine
AAR	Adaptive Autoregressive
LDA	Linear Discriminant Analysis
DWT	Discrete Wavelet Transform
FFT	Fast Fourier Transform
ROS	Robotic Operating System
RELU	Rectified Linear Function
RBFB	Radial Basic Function
ITSC	Intelligent Transportation Systems Conference

Lista de Figuras

2.1	Grafo de una Red Neuronal artificial. (Fuente: Scikit-Learn).	3
2.2	Frank Rosenblatntt ajustando un modelo perceptron en 1960.	4
2.3	Ejemplo de clasificacion según el kernel empleado. (Fuente: Scikit-Learn).	5
2.4	Cerebro humano con sus lóbulos diferenciados. (Fuente: Md Health.)	5
2.5	Actividad cerebral registrada con diferentes electrodos. (Fuente: About Kids Health).	6
2.6	Fotografía de una neurona por MethoxyRoxy. (Bajo licencia CC).	6
2.7	Disparo de una neurona y su símil como señal analógica y digital. (Fuente: Paul King, Quora)	7
2.8	Tipos de BCI. (Fuente: E. Astrand en [2]).	8
2.9	Casco de BCI. Fuente: BCI-Graz Awards 2016.	9
2.10	Sistema de posición 10-20 de electrodos de EEG. (Fuente: Chistopher B. bajo licencia CC).	9
3.1	Casco Mindwave Mobile. (Fuente: Neurosky).	11
3.2	Salida cruda obtenida del Mindwave Mobile.	11
3.3	Vehículo inteligente “iCab” con un pasajero usando el sensor de ondas cerebrales.	12
4.1	Salida muestreada desde el dispositivo Mindewave Mobile.	15
4.2	Formato de entrada para los clasificadores.	16
4.3	Ejemplo de interpolación lineal y cúbica.	17
5.1	Flecha animada en Unity3D.	21
5.2	Izquierda: Conocimiento sobre BCI. Derecha: Desconfianza que producen las técnicas de BCI.	24
5.3	Izquierda: Usuarios que controlarían un vehículo con su mente. Derecha: Usuarios que controlarían un ordenador con su mente.	25
C.1	Presupuesto desglosado del proyecto.	34

Lista de Tablas

4.1	Tabla de definición clave-valor.	16
4.2	Comparación de kernel para SVM	20
5.1	Resultados según la arquitectura del Experimento 1.	22
5.2	Resultados de la sesión de entrenamiento del Clasificador ‘B’.	23

Apéndice B

Marco Legislativo

En éste capítulo se va a enumerar la normativa por la que se ha regido el proyecto, la cual comprende la legislación del uso de vehículos automatizados actual de España.

La Dirección General de Tráfico junto al Ministerio del Interior dictamina que las pruebas con vehículos de conducción automatizada deben cumplir los siguientes requisitos:

1. Para toda prueba con vehículo autónomo se ha de redactar una solicitud para la realización de ensayos, entendiendo como vehículo automatizado todo vehículo que dispone de capacidad motriz equipado con tecnología que permita su manejo o conducción sin precisar la forma activa de control o supervisión de un conductor, tanto si dicha tecnología autónoma estuviera activada o desactivada de forma temporal o permanente.
2. La autorización tiene ámbito nacional y tendrá un plazo máximo de 2 años.
3. Debe haber siempre un conductor a los mandos del vehículo para poder maniobrar si fuera necesario.

Apéndice C

Aspecto Socio-Económico

En lo referente al coste del proyecto, se incluye tanto el coste del material empleado, como el coste del estudio y desarrollo del trabajo, los cuales se pueden ver en la Figura C.1.

CÓDIGO	UNIDAD DE MEDIDA	DESCRIPCIÓN	MEDICIÓN	PRECIO UNITARIO [€]	PRECIO TOTAL [€]
CAPÍTULO I: MATERIAL EMPLEADO					
1.01	Unidad	Ordenador personal: Ordenador de la marca Acer, empleado para la adquisición, y procesamiento de las señales de EEG enviadas por el sensor. Con el Sistema Operativo de libre distribución Linux, totalmente instalado y preparado.	1	650	650
1.02	Unidad	Neurosky Mindwave Mobile: Dispositivo comercial bluetooth de bajo coste de lectura de EEG de la empresa Neurosky.	1	99,99	99,99
1.03	Unidad	Vehículo autónomo iCab: Plataforma inteligente del Laboratorio de Sistemas Inteligentes de la Universidad Carlos III de Madrid. Totalmente funcional y preparado para conectarse con el sistema de BCI.	1	10.000	10.000
Precio total CAPÍTULO I					10.750
CAPÍTULO II: PERSONAL					
2.01	Hora	Trabajo del alumno: Horas empleadas por el alumno para realizar el diseño, las pruebas de campo, y la documentación del sistema BCI expuesto en este trabajo.	400	20	8.000
2.02	Hora	Tutorías: Horas empleadas por el ingeniero que ha tutorado al alumno.	100	32	3.200
Precio total CAPÍTULO II					11.200
PRECIO TOTAL					21.950

Figura C.1: Presupuesto desglosado del proyecto.

Este proyecto tiene un importante factor social ya que ofrece una primera aproximación de un sistema de bajo coste basado en la tecnología de las Interfaces Cerebro-Ordenador (BCI), que permita a las personas discapacitadas, o con problemas de movilidad, poder controlar la dirección de un vehículo, y así poder desempeñar tareas de la vida cotidiana u ofrecerles un trabajo digno.

Además, este trabajo puede ser empleado para controlar muchos más dispositivos, no solo vehículos, tan solo es necesario un ligero nivel de automatización de la máquina en cuestión, y unas pocas sesiones de entrenamiento del clasificador y del sujeto.

Referencias

- [1] T. Guerrero, “¿Cuántos años puede llegar a vivir un ser humano?” *El Mundo*, Abril 2014.
- [2] E. Astrand, C. Wardak, y S. Ben Hamed, “Selective visual attention to drive cognitive brainmachine interfaces: from concepts to neurofeedback and rehabilitation applications,” *Frontiers in Systems Neuroscience*, vol. 8, p. 144, 2014.
- [3] G. Klem, H. Lders, H. Jasper, y C. Elger, “The ten-twenty electrode system of the international federation,” *Electroencephalogr Clin Neurophysiol*, vol. 52, pp. 3–6, 1999.
- [4] C. Guger, A. Schlogl, C. Neuper, D. Walterspacher, T. Strein, y G. Pfurtscheller, “Rapid prototyping of an eeg-based brain-computer interface (bci),” *IEEE Transactions on Neural Systems and Rehabilitation Engineering*, vol. 9, no. 1, pp. 49–58, 2001.
- [5] C. Guger, G. Edlinger, W. Harkam, I. Niedermayer, y G. Pfurtscheller, “How many people are able to operate an eeg-based brain-computer interface (bci)?” *IEEE transactions on neural systems and rehabilitation engineering*, vol. 11, no. 2, pp. 145–147, 2003.
- [6] B.-G. Xu y A.-G. Song, “Pattern recognition of motor imagery eeg using wavelet transform,” *Journal of Biomedical Science and Engineering*, vol. 1, pp. 64–67, 2008.
- [7] C. Jennifer, et al., “High-performance neuroprosthetic control by an individual with tetraplegia,” *The Lancet*, vol. 381, pp. 557–564, Diciembre 2012.
- [8] L. Al-Barrak y E. Kanjo, “Neuroplace: Making sense of a place,” *4th Augmented Human International Conference*, pp. 186–189, 2013.
- [9] A. Vourvopoulos y F. Liarakis, “Robot navigation using brain-computer interfaces,” Master’s thesis, Coventry University, 2012.
- [10] K. Stamps y Y. Hamam, “Towards inexpensive bci control for wheelchair navigation in the enabled environment,” *Brain Informatics Lecture Notes in Computer Science*, vol. 6334, pp. 336–345, 2010.

- [11] E. A. Larsen, “Classification of eeg signals in a brain - computer interface system,” Master’s thesis, Norwegian University of Science and Technology, 2011.
- [12] P. Marin-Plaza, J. Beltran, A. Hussein, B. Musleh, D. Martin, A. de la Escalera, y J. M. Armingol, “Stereo vision-based local occupancy grid map for autonomous navigation in ros,” *Joint Conference on Computer Vision, Imaging and Computer Graphics Theory and Applications (VISIGRAPP)*, vol. 3, pp. 703–708, 2016.
- [13] S. Ataucuri, “Ros neural,” *Google Summer of Code 2015*, 2015.
- [14] A. Hussein, P. Marin-Plaza, D. Martin, A. de la Escalera, y J. M. Armingol, “Autonomous off-road navigation using stereo-vision and laser-rangefinder fusion for outdoor obstacles detection,” *IEEE Intelligent Vehicles Symposium (IV)*, pp. 104–109, 2016.
- [15] NeurosSky, “Thinkgear serial stream guide,” *NeurosSky*, 2015.
- [16] H. B. Demuth, M. H. Beale, O. De Jess, y M. T. Hagan, *Neural network design*. Martin Hagan, 2014.
- [17] F. Pedregosa, et al., “Scikit-learn: Machine learning in Python,” *Journal of Machine Learning Research*, vol. 12, pp. 2825–2830, 2011.
- [18] A. Astudillo, F. Moreno, A. Hussein, y F. García, “Cost-efficient brainwave controller for automated vehicles route decisions,” *IEEE Intelligent Transportation Systems Conference*, 2017.